

基于改进 YOLOv5 的轻量化玻璃绝缘子 自爆缺陷检测研究

王道累, 张世恒, 袁斌霞, 赵文彬, 朱 瑞
(上海电力大学能源与机械工程学院, 上海 200240)

摘要: 为了维持电力传输的可靠性、安全性和可持续性, 航拍玻璃绝缘子的自爆缺陷诊断成为电力巡检中一项重要的任务。为此, 提出了一种轻量化的玻璃绝缘子自爆缺陷检测模型 L-YOLOv5。首先, 对主干网络中的残差模块进行轻量化改进, 添加深度可分离卷积和 1×1 组卷积, 设计主干网络 L-CSPDarknet53, 此网络可以有效提高模型检测速度。在特征提取方面, 设计了 DC-SPP 模块, 模块中卷积与空洞卷积串联的方式可以在不损失细节信息的情况下增大感受野, 提高网络的检测性能。最后, 针对自爆缺陷区域小难以检测的问题, 提出增加小目标检测层的方法, 小目标检测层包含更多缺陷细节信息, 更加有利于自爆缺陷的检测。实现结果表明, L-YOLOv5 可以快速准确的检测自爆缺陷, 其中准确率可达到 96.7%, 检测速度达到 37.4 帧/s, 相比于 YOLOv5 网络, 准确率和速度分别提升了 3.5% 和 49%。与 Faster-RCNN、SSD 等常用检测网络相比, L-YOLOv5 在绝缘子缺陷识别和定位问题上具有更强的竞争力。

关键词: 轻量化; 玻璃绝缘子; 自爆缺陷; 深度可分离卷积; 空洞卷积

Research on Self-explosion Defect Detection of Lightweight Glass Insulators Based on Improved YOLOv5

WANG Daolei, ZHANG Shiheng, YUAN Binxia, ZHAO Wenbin, ZHU Rui

(College of Energy and Mechanical Engineering, Shanghai University of Electric Power, Shanghai 200240, China)

Abstract: In order to maintain the reliability, safety and sustainability of power transmission, the fault diagnosis of aerial insulators has become an important task in power inspection. Therefore, a lightweight defect detection model L-YOLOv5 is proposed in this paper. First, the residual module in the backbone network is improved for light weight by adding depthwise separable convolution and 1×1 group convolution, and by designing the backbone network L-CSPDarknet53. This network can greatly improve the detection speed without sacrificing a small amount of accuracy. In terms of feature extraction, the DC-SPP module is designed. The convolution and dilated convolution in the module can increase the receptive field and improve the detection performance of the network without losing detailed information. Finally, in accordance with the problem that the self explosion defect area is small and difficult to detect, a method of adding a small target detection layer is proposed. The small target detection layer contains more defect details, which is more conducive to the detection of self explosion defects. The implementation results show that L-YOLOv5 can quickly and accurately detect self explosion defects, with an accuracy of 96.7% and a detection speed of 37.4 frames/s. Compared with YOLOv5 network, the accuracy and speed are improved by 3.5% and 49%, respectively. Compared with other common detection networks such as Faster R-CNN and SSD, L-YOLOv5 is more competitive in insulator defect identification and location.

Key words: lightweight; glass insulator; self exploding defects; depthwise separable convolution; dilated convolution

0 引言

当今, 智能化巡检已成为输电线路巡检发展的新趋势。作为输电线路的基本构件, 绝缘子在电气

隔绝和机械支撑方面发挥着重要作用^[1-2]。绝缘子长期暴露在外界环境中, 会遭受恶劣天气、鸟粪和人为因素的干扰, 从而产生腐蚀、污秽、自爆等缺陷。其中, 自爆缺陷是最容易发生且威胁较大的缺陷。因此, 定期对绝缘子进行巡检, 对于避免大型输电线路事故的发生具有重大的意义^[3]。当前输电线路的巡检方式主要有有人工巡检^[4]、直升机巡检、攀爬

基金资助项目: 国家自然科学基金(12172210; 61502297)。
Project supported by National Natural Science Foundation of China (12172210, 61502297).

机器人巡检^[5]和无人机巡检。输电线路大多处于山区环境中, 人工巡检难度较大, 检测效率低。直升机巡检成本较高, 同时受地形限制灵活性差, 危险系数高。无人机巡检以其成本低、灵活性好、效率高的优点逐渐成为输电线路巡检的主要方式。面对无人机巡检拍摄的大量巡检图像, 由人工判读的话效率会十分低下, 同时也会容易出现绝缘子缺陷漏判、错判等情况, 而基于深度学习的目标检测方法为这一问题的解决提供了有力的研究思路。目前, 学者研究绝缘子自爆缺陷检测方法的主要关注点分为两种, 一种是注重检测精度的提升, 通过添加性能优异的模块大幅提升检测精度, 但也会导致权重过大, 检测速度下降; 另一种是注重检测速度的提升, 通过对模型进行剪枝压缩, 大幅提升模型的检测速度以及嵌入式部署的可行性, 但也会一定程度对检测效果产生影响。

在注重检测精度的研究中, LING Z N 等人提出了 Faster RCNN 和 U-Net 结合的方法^[6-8], Faster RCNN 用于定位玻璃绝缘子串, U-Net 用于对不同大小的裁剪图像中的像素进行准确分类, 检测精度和召回率分别达到了 94.9%和 95.4%。王道累等人使模型学习正常绝缘子的特征, 并利用生成对抗网络重建缺陷绝缘子, 通过改进的差异评分实现绝缘子伞盘脱落缺陷的检测^[9]。种法广等人使用 K-means++匹配出新的绝缘子缺陷锚点坐标^[10], 并在 YOLOv3 算法^[11]中增加了通道注意力机制 SENet 结构, 有效提升了绝缘子缺陷的检测精度。李斌等人提出上下文感知缺陷检测网络, 通过改进特征金字塔以及增加感受野自适应模块对多尺度上下文信息进行融合, 实现绝缘子缺陷精确识别与定位^[12]。在注重检测速度与轻量化的研究中, YU J M 等人对 YOLOv4 主干网络 CSPDarkNet53 进行了改进, 同时使用自适应图像缩放算法对输入图像进行了预处理, 改进后的模型有效地减少了计算量和冗余度^[13]。卞建鹏等人实现了胶囊网络与 YOLO 文本定位的结合, 并通过遗传算法和随机梯度下降法对权重进行寻优, 大大降低了网络训练时间与计算成本^[14], 实现了更加快速的绝缘子破损位置的定位。ZHA M F 等人使用 MobileNetv2 对 YOLOv4 主干网络进行替换, 并增加坐标注意力机制, 实现检测网络的轻量化^[15]。苟军年等人利用计算成本较低的 GhostNet 对 CenterNet 网络进行改进, 进而提取自爆绝缘子的多层次特征^[16-17], 改进后的模型参数量由

124.61M 减少至了 64.2M。贾晓芬等人针对 YOLOv3 中的特征提取网络与空间金字塔池化(spatial pyramid pooling, SPP)模块进行了轻量化改进^[18-19], 改进后网络在保证绝缘子自爆缺陷检测精度和速度的前提下, 将模型权重大小降低到了 13.61 M。上述检测方法分别在检测精度与权重轻量化方面对绝缘子缺陷检测模型进行了优化, 但多数改进后的模型参数量仍然较大, 很难实现在嵌入式设备上的部署。

为了在保证精度的前提下实现无人机航拍绝缘子图像的实时检测, 本文提出了一种轻量化绝缘子自爆缺陷检测模型 L-YOLOv5, 该模型通过深度可分离卷积对主干网络进行了计算量优化, 在特征提取方面对 SPP 模块进行了改进, 最后在 3 层检测层的基础上增加了尺度为 160×160 的小目标检测层。利用本文构建绝缘子缺陷数据集对模型进行训练, 实验结果表明, 本文提出的模型检测精度高、速度快、参数量小, 可以为输电线路绝缘子自爆缺陷的实时检测提供有效的参考。

1 L-YOLOv5 网络结构

1.1 L-YOLOv5 网络结构

YOLOv5 网络模型在目标检测领域具有突出的表现, 但由于绝缘子自爆缺陷目标较小, 所处背景复杂, 大大增加了检测难度, 为了提升自爆缺陷的检测精度和效率, 本文提出了基于 YOLOv5 改进的绝缘子自爆缺陷检测模型 L-YOLOv5。模型如图 1 所示, 它主要由主干网络、特征金字塔模块和检测头 3 个部分构成。

本文对上述 3 个部分别进行了不同形式的改进。一是在主干网络残差模块中利用深度可分离卷积^[20]对普通卷积进行替换, 利用 1×1 的组卷积对 1×1 卷积进行替换, 并在 short cut 上添加 3×3 的平均池化处理, 构建出新的主干网络 L-CSPDarknet53, 它可以实现在降低少量精度的情况, 大幅降低模型参数量, 提高检测速度。二是在特征金字塔模块中, 对 SPP 结构进行改进, 增加卷积操作进行特征提取, 同时用空洞卷积(dilated convolution, DC)代替最大池化, 构建出 DC-SPP 模块。该模块一方面能够增加特征图的信息含量, 另一方面可以在不降低模型计算速度的情况下增大特征图的感受野, 有效提升特征图中全局信息含量。三是针对自爆缺陷小目标的特点, 对主干网络中的

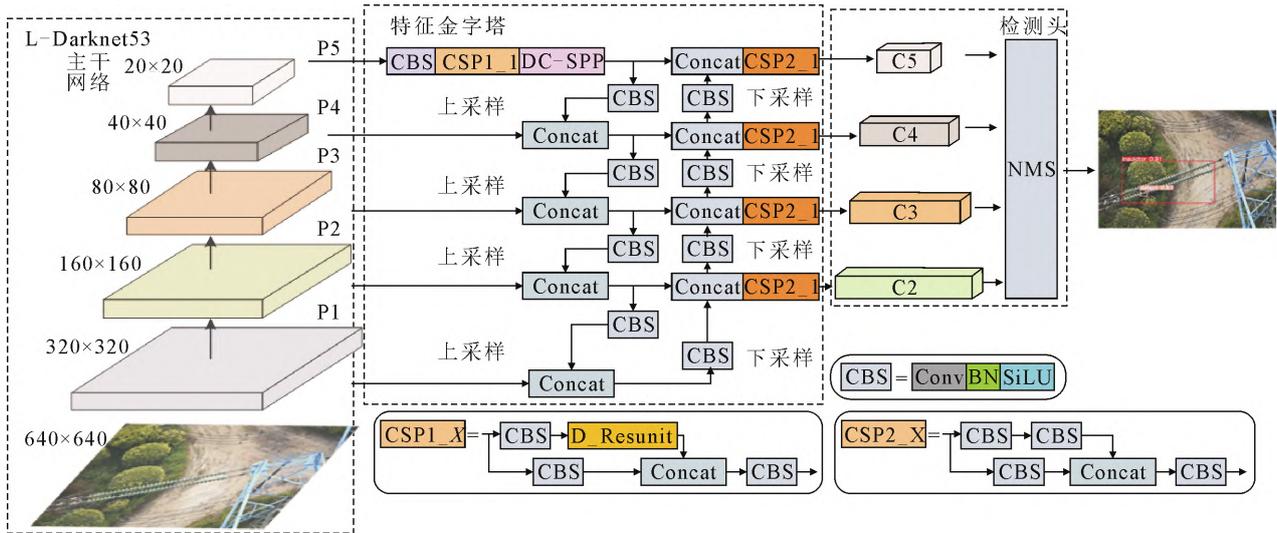


图1 L-YOLOv5 网络结构

Fig.1 L-YOLOv5 network structure

浅层特征图进行重新利用，构建四检测层的检测头结构，提升模型对自爆缺陷的检测精度。

1.2 主干网络 L-CSPDarknet53

在实际工程应用中，目标检测算法可以在服务器等高性能计算机上实现实时检测，但在图像采集、传输、加密、检测等过程中浪费了大量的时间，间接导致检查人员难以及时采取措施。此外，将模型移植到手机等嵌入式设备时，由于处理器性能不足，难以获得检测结果。为此，本文提出了一种轻量化的主干网络 L-CSPDarknet53，如图 2 所示。该网络主要由 3 个 CSP1_X(X=1、2、3)模块组成，该模块分为 2 个分支，分支 1 为常规卷积操作进行特征提取，分支 2 为多个残差模块的叠加，其中 CBS 为 Conv+BN+SiLU 的集合，残差模块能够增加网络深度，提高性能，最后将两分支结果进行拼接。

本文主要对 CSP1_X 结构中的残差模块进行了改进，借鉴 ShuffleNetV1 中的残差单元，构建出 D_Resunit，改进前后 CSPDarknet53 网络中残差模块结构对比如图 3 所示，将原模块中的 1×1 卷积和普通卷积分别利用 1×1 组卷积和深度可分离卷积进行替换，并在 short cut 上添加 3×3 的平均池化处理，同时利用 MetaAconC 激活函数模块进行优化。

特征图经过组卷积后实现通道上的分组并分别进行卷积，组卷积能够在一定程度上降低模型的计算量，但也会对特征图不同通道之间的信息沟通产生一些影响。

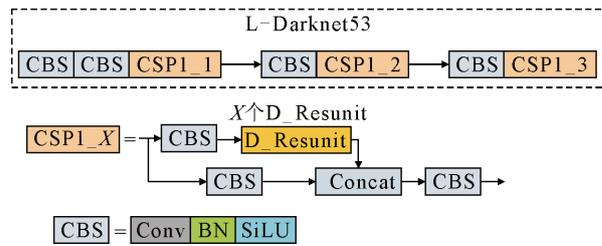


图2 L-CSPDarknet53 网络结构

Fig.2 L-CSPDarknet53 network structure

组卷积与普通卷积的参数量比例为：

$$\frac{N(C/G)K^2}{NCK^2} = \frac{1}{G} \tag{1}$$

式中：N 为卷积核个数；C 为输入通道数；G 为组数；K 为卷积核大小。由式(1)可以看出，分组卷积的参数量是普通卷积的 1/G。

然后对输出结果进行批量归一化以及 MetaAconC 激活函数处理，其中 MetaAconC 激活函数通过明确学习非线性和线性之间的参数切换，自适应地选择是否激活神经元，有效防止了神经元由于模型参数更新太大而产生的坏死。随后进行 C Mashup 操作，将卷积后的特征进行通道混洗，增加通道间的沟通，降低组卷积带来的不良影响。然后利用深度可分离卷积进行进一步特征提取，深度可分离卷积由 2 种不同的卷积形式组合而成，一为逐通道卷积(DWConv)，它可以针对每个输入通道应用不同的卷积核，1 个卷积核对应 1 个输入通道，然后对输出结果进行逐点卷积；二为逐点卷积

(PWConv)其功能与同普 1×1 卷积相同。改进后的卷积参数量对比如式(2)所示。

$$\frac{D_k^2 M D_F^2 + M N D_F^2}{D_k^2 M N D_F^2} = \frac{1}{N} + \frac{1}{D_k^2} \quad (2)$$

式中: M 为输入通道数及逐通道卷积核个数; N 为输出通道数, 即逐点卷积核个数; D_F 为输入特征图大小; D_k 为卷积核大小。计算式中分子为逐通道卷积计算量与逐点卷积计算量之和, 分子为标准卷积计算量。

在网络训练时卷积核个数 N 一般较大, 故计算式中的参数量占比主要取决于卷积核大小 D_k 。如图 3 所示, 改进后的残差模块采用 3×3 大小的逐通道卷积, 故模块中深度可分离卷积的参数量约为普通卷积的 $1/9$ 。

最后, 在残差模块的 short cut 上添加 3×3 的平均池化操作, 对模型计算量进行进一步优化, 将池化后的结果与深度可分离卷积操作后的结果进行通道上的拼接, 输出残差单元提取到的特征图。

综上, 改进后的残差模块分别在多角度上进行了计算量的优化处理, 有效地降低了模型的参数量, 提高模型在检测速度方面的性能。

1.3 特征金字塔模块

YOLOv5 网络中的 SPP 模块能够将任意大小的特征图转换成固定大小的特征向量, 有利于后续的全连接操作; 同时它也可以提取不同尺度的空间特征信息, 提升特征图中空间整体特征的表达。但模块中的最大池化操作会带来一定程度特征信息的损失, 这对于自爆缺陷这样的小目标是十分不利的。为此, 设计了一种基于特征提取的空洞卷积空间金字塔池化模块 DC-SPP, 结构图如图 4 所示, 该模块能够有效解决自爆缺陷因目标小导致的检测精度低的问题。

图 4 所示的 DC-SPP 是在 SPP 模块的基础上, 引入空洞卷积对池化操作进行了替换, 空洞卷积前各增加不同尺度的普通卷积进行特征提取, 同时在 shortcut 上增加可适应平均池化处理, 实现网络速度、性能双提升的效果^[21]。此模块特征提取的过程为:

1) 对于主干网络 L-CSPDarknet53 输出的特征图, 分别送入 4 条并行分支, 其中 1 条为增加可适应平均池化的 shortcut, 其他 3 条均为由 1×1 卷积层、普通卷积层以及空洞卷积层级联构成。由于本文更加关注绝缘子自爆缺陷小目标的检测, 因此 3 个空洞卷积的扩张率(dilation rate)设置较小, 分别为 1、3、5。

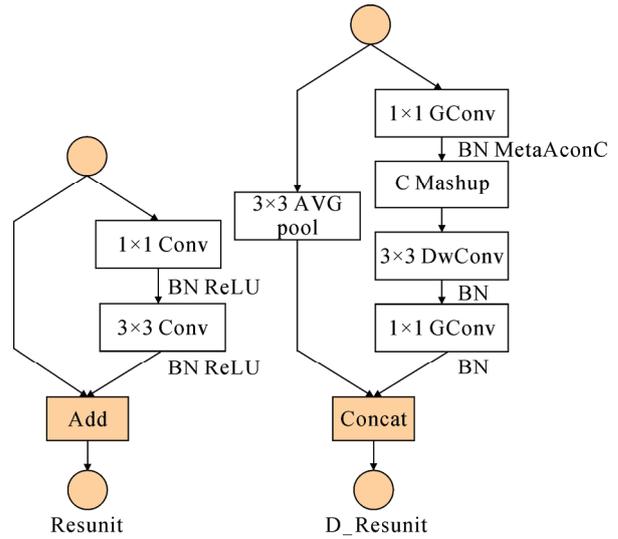


图 3 Resunit 和 D_Resunit 结构图

Fig.3 Structure diagram of Resunit and D_Resunit

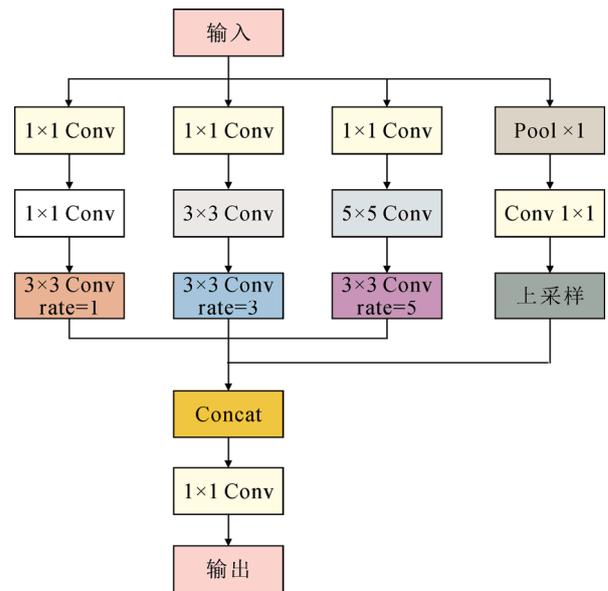


图 4 DC-SPP 结构

Fig.4 DC-SPP structure

2) 对 4 条分支得到的结果进行 Concat 相加, 融合同一特征图中不同尺度的特征信息。

3) 对特征融合后的结果进行 1×1 的卷积处理, 调整输出通道, 得到最后的输出结果。

其中 3 条含空洞卷积的支路增加了 1×1 卷积, 一方面能够降低网络计算量, 另一方面便于 3 条支路输出结果的拼接。该模块对输入的特征进行了不同扩张率的空洞卷积操作, 与池化作用相似, 能后提取同一特征图不同尺度的特征信息, 不同的是空洞卷积缓解了池化操作带来的信息损失问题, 丰富

了特征图中绝缘子以及自爆缺陷的局部特征信息含量。第4支路上的可适应性平均池化操作更能够对全局信息进行抽象浓缩。将局部特征与全局信息进行融合,提高网络的检测性能。

1.4 小目标检测层

航拍绝缘子图像中,一般自爆缺陷目标较小,并且与背景环境中的一些物体有很高的相似性,对缺陷的检测效果带来很大的影响。为此,在网络原3个检测层的基础上,增加了1个尺度为 160×160 的小目标检测层,构建出的整体结构如图5所示。

图5中 $L_i(i=1,2,3,4,5)$ 为经过主干网络和特征金字塔上采样后输出的5个不同尺度的特征图。将 $L_i(i=2,3,4,5)$ 4个特征图分别与上层特征图下采样的结果进行拼接,再经过CSP(卷积+拼接)模块,得到4个不同尺度的检测层。4个检测层对应的特征图分辨率分别为 160×160 、 80×80 、 40×40 、 20×20 。然后对每个特征图使用个数为21大小为 1×1 的卷积核进行卷积操作,得到 $N \times N \times 21(N$ 取160、80、40、20)的结果,将其划分为 $N \times N$ 的网格。其中取21个卷积核的原因每一个单元网格对应3个不同大小的先验框(即 anchor),每一个先验框需要7个预测结果(类别信息(绝缘子或自爆缺陷)、置信度信息、坐标信息为 (x, y, h, w)),故每个网格对应21个参数信息,对其中先验框坐标信息参数进行调整后,输出对应到原图中的类别信息、置信度以及预测框坐标信息。其中分辨率高的特征图包含更多图像中的细节信息,因此能够缓解特征提取较深带来的自爆缺陷信息丢失的问题,有效提升模型针对缺陷小目标的检测效果。最后将得到的与原图匹配的预测框进行非极大值抑制(non-maximum suppression, NMS)处理,也就是筛选出一定区域内同一类别得分最大的预测框,然后将预测框以及类别、置信度等信息绘制到原图上,得到最终自爆缺陷的检测结果。

2 实验结果与分析

2.1 数据集构建

采用网络开源绝缘子缺陷数据集 (Chinese power line insulator dataset, CPLID) 以及网络中收集到的40张带有自爆缺陷的绝缘子图像作为模型训练的数据集。CPLID数据集中包含600张正常绝缘子图像以及248张带有自爆缺陷的绝缘子图像。为了增加实验数据集的丰富性以及避免训练过程中

产生过拟合现象,利用数据增强技术对绝缘子数据集进行处理。具体为使用增加高斯噪声、模糊、改变亮度、增加掩码和旋转等方式对原始图像的样式进行转换,数据增强后的结果如图6所示。最终绝缘子数据共有7104张,其中正常绝缘子图像为4800张,缺陷绝缘子图像为2304张,将数据集按照4:1的比例进行划分,5684张图像作为训练集,剩余1420张图像作为验证集。

2.2 实验环境配置

本实验中采用python语言作为编程语言,使用pytorch深度学习框架构建检测模型,实验操作系统为Ubuntu16.04, GPU为NVIDIA Tesla T4(16G显存)。实验相关参数设置如表1所示。

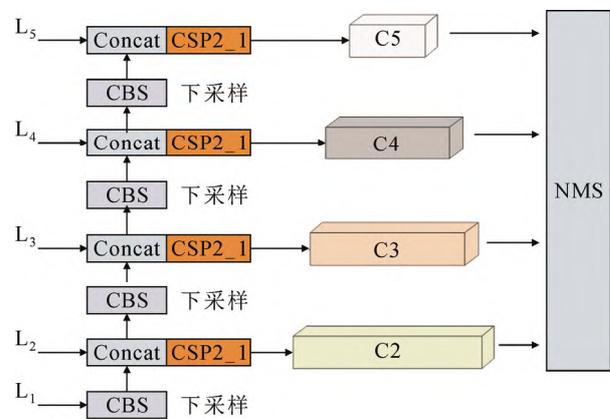


图5 四检测层模型

Fig.5 Four detection layer model



图6 数据增强

Fig.6 Data enhancement

表1 实验参数设置

参数名称	参数值
批处理大小	4
图片尺寸	640×640
学习率	0.01
动量	0.937
衰减系数	0.0005
迭代轮次	200

2.3 评价指标

为了比较不同物体检测模型针对绝缘子自爆缺陷的检测精度, 选取平均准确率 P_A 作为评价模型精度性能的指标。其中 P_A 由准确率 P 和召回率 R 计算而来, P 、 R 的计算式分别为:

$$P = \frac{T_p}{T_p + F_p} \quad (3)$$

$$R = \frac{T_p}{T_p + F_N} \quad (4)$$

式中: T_p 为正样本被识别的数量; F_p 为负样本被误报的数量; F_N 为正样本被漏报的数量。以计算得到的准确率和召回率为纵横坐标绘制 $P-R$ 曲线, 曲线下面积为 P_A 值, P_A 的计算式为:

$$P_A = \int_0^1 P(R)dR \quad (5)$$

为了比较不同物体检测模型的检测速度, 反映实时检测能力, 本文选择引入每秒帧数 N_{FPS} 作为评价指标, 即模型检测一张图像所花费的时间。为了比较不同物体检测模型实现嵌入部署的能力, 本文引入参数量 P_{Params} 作为评价指标, 参数量小的模型更容易实现嵌入式部署。

2.4 模型训练

采用数据增强后的绝缘子缺陷数据集对 L-YOLOv5 网络模型进行训练, 训练时使用随机梯度下降优化器 (stochastic gradient descent, SGD) 和余弦退火策略调整学习率。同时使用相同参数策略对 YOLOv5 模型进行训练, 改进前后模型训练损失如图 7 所示, 可以看出 L-YOLOv5 在训练集和验证集上的损失收敛效果均优于原模型, 其中训练和验证损失在收敛后的数值分别比 YOLOv5 降低了 0.0048 和 0.0057。

改进前后模型的准确率曲线如图 8 所示, 由图 8 中信息分析得出, L-YOLOv5 的准确率和召回率均高于原模型的。当交并比(intersection over union, IOU)阈值 > 0.5 时, 改进后模型平均准确率 $P_{mA}(0.5)$ 提升了 3.3%, 当 IOU 阈值取 0.5~0.95、步长 0.05 的不同 IOU 值时, 平均准确率 $P_{mA}(0.5:0.95)$ 提升了 12.5%。上述结果均说明, 本文基于轻量化特点对 YOLOv5 提出的改进策略, 可以有效优化网络性能, 提升网络检测的准确率。

2.5 实验结果与分析

2.5.1 不同检测模型对比试验

为了验证本文所提检测模型的有效性, 还构建了其他 3 种类型的目标检测模型作为对比, 包括

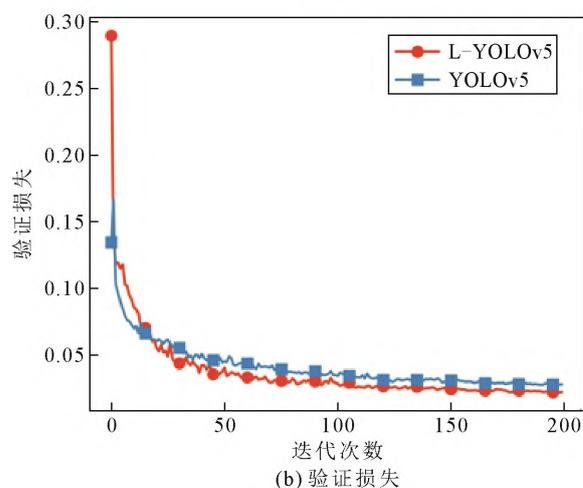
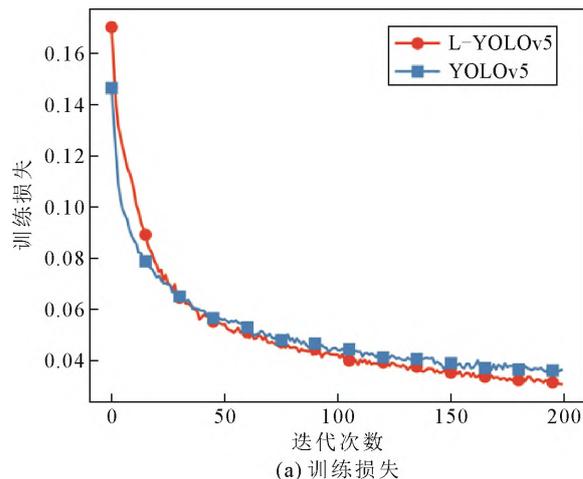


图 7 模型损失曲线

Fig.7 The curve of model loss

Faster R-CNN、SSD 和 Efficientdet。使用相同绝缘子缺陷数据集和相同训练集验证集划分策略对这些目标检测模型进行训练。实验结果如表 2 所示。

由表 2 可知, 与经典的目标检测模型 Faster R-CNN、SSD、Efficientdet 相比, L-YOLOv5 的检测速度、平均准确率均为最高且模型参数量最少。在两阶段目标检测模型中以 ResNet50 为主干网络的 Faster R-CNN, 其 P_A 值达到了 94.2%, 但其模型参数量较大, 检测速度仅为 3.3 帧/s, 难以满足实际应用需求。在单阶段目标检测模型中, 以本文改进的 L-CSPDarknet53 为主干网络的 L-YOLOv5 的检测精度最高, 检测速度为 37.4 帧/s, 检测速度优于 SSD、Efficientdet 两种目标检测模型。相较于 YOLOv5, 本文通过对主干网络残差模块的改进, 大幅减轻了模型大小, 提升了检测速度, 但也使得检测精度有所下降。在对 SPP 模块与检测层的改进中, 致力于提升检测精度, 使得模型权重增大, 检

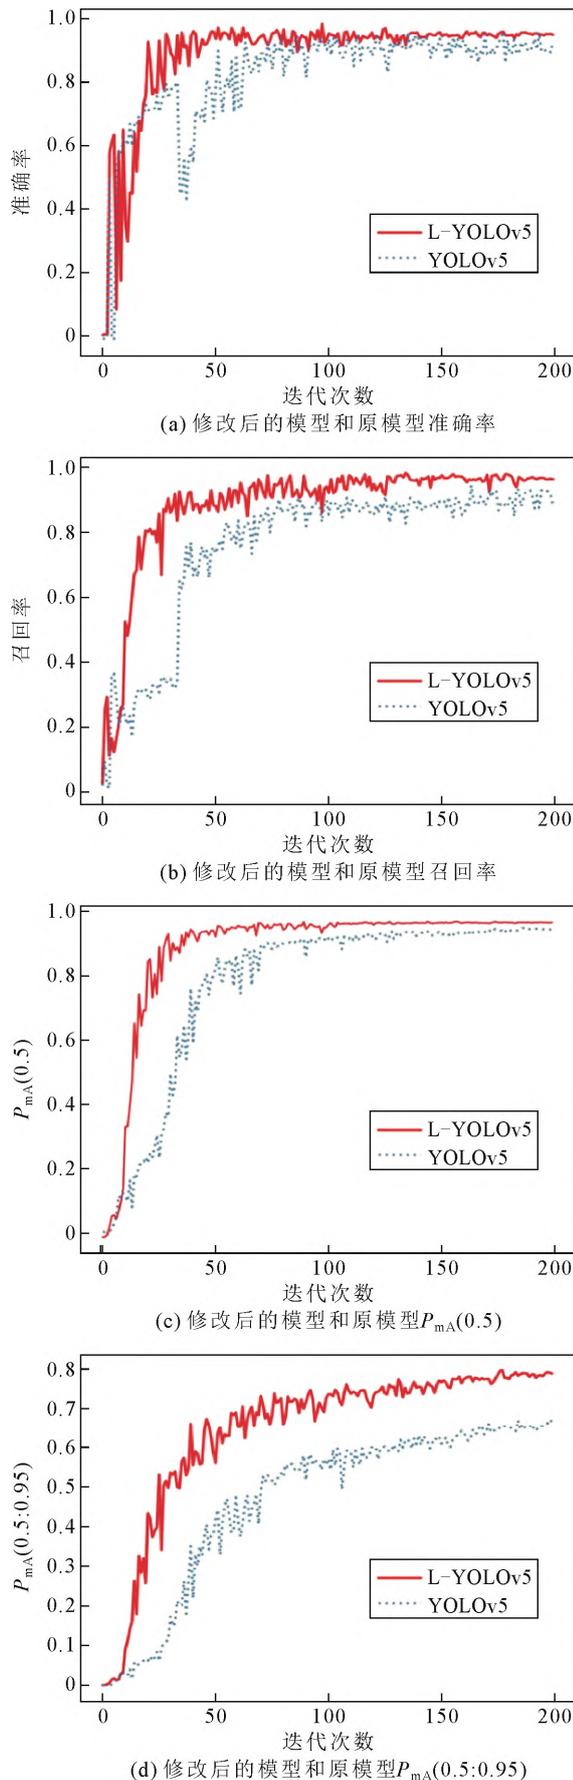


图8 模型准确率曲线

Fig.8 Curve of model accuracy

测速度有所上升。将上述三点改进共同应用于YOLOv5, 最终模型在所关注方面都有相应提升, 且在模型轻量化方面提升较为明显。可见, 本文模型实现了在缺陷检测精度和速度方面的综合提升, 最终效果能满足对绝缘子缺陷的实时检测需求。

为了能够对改进前后模型的性能进行更加直观的分析, 本文对改进前后模型的检测结果进行了展示, 如图9所示, 其中①、②、③代表了两模型检测结果差异之处, 可以看出, 原网络模型在①、③处出现了绝缘子缺陷漏检问题, 在②处出现了绝缘子错检问题, 而本文改进后的L-YOLOv5模型, 精确检测出了图像中的绝缘子缺陷, 并对图像中的绝缘子进行了准确的定位, 有效地避免了自爆缺陷错检漏检的问题。

2.5.2 消融实验

为了验证L-YOLOv5模型中的改进对原网络模型所带来性能提升, 依次在原网络模型基础上增加L-CSPDarknet53 主干网络、DC-SPP 模块以及小目标检测层这3种改进方法, 以相同数据集和同种训练策略进行消融实验, 实验结果如表3所示。

实验1是将YOLOv5的主干网络CSPDarknet53 替换为改进后的L-CSPDarknet53 网络, 替代后的网络 P_A 值比YOLOv5 降低了0.9%, 但模型参数下降

表2 不同模型对比

Table 2 Comparison of different models

模型	主干网络	$P_A/\%$	$N_{FPS}/(\text{帧}\cdot\text{s}^{-1})$	$P_{Params}/10^6$
Faster R-CNN	ResNet50	94.2	3.3	108.9
SSD	Vgg16	81.4	20.3	100.3
Efficientdet	EfficientNet-B0	82.5	14.4	15.1
YOLOv5	CSPdarkent53	93.4	25.1	13.7
L-YOLOv5	L-CSPDarknet53	96.7	37.4	3.4



图9 检测效果对比

Fig.9 Comparison of detection results

表 3 消融实验

Table 3 Ablation experimental

模型 类型	L- CSPDarknet53	DC- SPP	小目 标层	$P_A/\%$	$N_{FPS}/$ (帧·s ⁻¹)	$P_{Params}/$ 10 ⁶
原模型				93.4	25.1	13.7
实验 1	✓			92.6	40.4	3.1
实验 2	✓	✓		94.6	37.9	3.3
实验 3	✓	✓	✓	96.7	37.4	3.4

了 77%，检测速度提升了 61%。实验 1 在牺牲较少检测精度的情况下，实现了模型在检测速度和参数量方面的优化提升。实验 2 在实验 1 的基础上加入了 DC-SPP 模块，网络模型的参数量略微增加， P_A 值较实验 1 提升了 2.2%，其原因主要由于 DC-SPP 模块中的空洞卷积降低了特征图信息的损失而卷积特征提取部分增加了少量参数量，但模型的整体性能得到了提升。实验 3 在实验 2 的基础上加入了小目标检测层，在 YOLOv5 模型 3 层检测层的基础上，增加了 1 个尺度为 160×160 的检测层，提升了模型对缺陷小目标的检测效果，可以看出 P_A 值与实验 2 相比增加了 2.2%。通过表 2 的实验结果可知，L-YOLOv5 中提出的 3 种改进策略在效果上看起来略微有所矛盾，但实际在实现目标功能(保证精度情况下的轻量化改进)的过程中是不断递进的，3 种改进策略设计合理，有助于提升模型的综合性能，使模型具有更好的检测效果。

3 结论

1) 针对缺陷检测模型检测速度慢、权重大难以部署问题，设计了一种新的主干网络 L-CSPDarknet53，实现了检测速度的大幅提升。

2) 针对自爆缺陷目标小检测困难问题，设计 DC-SPP 模块，避免了训练过程中池化操作带来的信息损失，提升了特征图的特征含量，

3) 增加小目标检测层，对骨干网络中的浅层特征层进行重新利用，增大检测层尺度，提高模型对缺陷小目标的检测性能。

实验结果表明，相较于 YOLOv5，本文所提模型的缺陷检测准确率达到 96.7%， N_{FPS} 达到了 37.4 帧/s，参数量降低为 3.4×10^6 。综上，本文提出的 L-YOLOv5 模型可以准确快速地识别出航拍图像中的绝缘子自爆缺陷，能够满足实际巡检应用的需求。

参考文献 References

[1] PARK K C, MOTAI Y, YOON J R. Acoustic fault detection technique

for high-power insulators[J]. IEEE Transactions on Industrial Electronics, 2017, 64(12): 9699-9708.

[2] WANG J F, LIANG X D, GAO Y F. Failure analysis of decay-like fracture of composite insulator[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2014, 21(6): 2503-2511.

[3] QIU Z B, ZHU X, LIAO C B, et al. Detection of transmission line insulator defects based on an improved lightweight YOLOv4 model[J]. Applied Sciences, 2022, 12(3): 1207.

[4] NGUYEN V N, JENSSEN R, ROVERSO D. Automatic autonomous vision-based power line inspection: a review of current status and the potential role of deep learning[J]. International Journal of Electrical Power & Energy Systems, 2018, 99: 107-120.

[5] KATRASNİK J, PERNUS F, LIKAR B. A survey of mobile robots for distribution power line inspection[J]. IEEE Transactions on Power Delivery, 2010, 25(1): 485-493.

[6] LING Z N, ZHANG D X, QIU R C, et al. An accurate and real-time method of self-blast glass insulator location based on faster R-CNN and U-net with aerial images[J]. CSEE Journal of Power and Energy Systems, 2019, 5(4): 474-482.

[7] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[C] // Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge, United States: MIT Press, 2015: 91-99.

[8] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich, Germany: Springer, 2015: 234-241.

[9] 王道累, 孙嘉璐, 张天宇, 等. 基于改进生成对抗网络的玻璃绝缘子自爆缺陷检测方法[J]. 高电压技术, 2022, 48(3): 1096-1103. WANG DaoLei, SUN JiaJun, ZHANG Tianyu, et al. Self-explosion defect detection method of glass insulator based on improved generative adversarial network[J]. High Voltage Engineering, 2022, 48(3): 1096-1103.

[10] 种法广, 温 蜜, 田英杰, 等. 基于注意力机制的多尺度缺陷绝缘子检测算法[J]. 计算机仿真, 2022, 39(7): 137-142, 147. ZHONG Faguang, WEN Mi, TIAN Yingjie, et al. Multi-scale defect insulator detection algorithm based on attention mechanism[J]. Computer Simulation, 2022, 39(7): 137-142, 147.

[11] REDMON J, FARHADI A. Yolov3: An incremental improvement[J]. arXiv preprint arXiv: 1804.02767, 2018.

[12] 李 斌, 曾筠婷, 朱新山, 等. 基于多尺度上下文感知的绝缘子缺陷检测网络[J]. 高电压技术, 2022, 48(8): 2905-2914. LI Bin, ZENG Yunting, ZHU Xinshan, et al. Detection network for insulator defects based on multi-scale context awareness[J]. High Voltage Engineering, 2022, 48(8): 2905-2914.

[13] YU J M, ZHANG W. Face mask wearing detection algorithm based on improved YOLO-v4[J]. Sensors, 2021, 21(9): 3263.

[14] 卞建鹏, 李 凡, 郝培旭, 等. 复杂环境下输电线路绝缘子的破损识别与定位[J]. 高电压技术, 2022, 48(2): 681-688. BIAN Jianpeng, LI Fan, HAO Peixu, et al. Damage identification and location of transmission line insulator in complex environment[J]. High Voltage Engineering, 2022, 48(2): 681-688.

[15] ZHA M F, QIAN W B, YI W L, et al. A lightweight YOLOv4-based forestry pest detection method using coordinate attention and feature fusion[J]. Entropy, 2021, 23(12): 1587.

[16] 苟军年, 杜慷慷, 王世铎, 等. 轻量化特征融合的 CenterNet 输电线路绝缘子自爆检测[J/OL]. 北京航空航天大学学报, 2022: 1-13 [2022-11-29]. <https://doi.org/10.13700/j.bh.1001-5965.2022.0602>.

GOU Junnian, DU Susu, WANG Shiduo, et al. Lightweight feature fusion CenterNet transmission line insulator self-explosion detection[J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 2022: 1-13[2022-11-29]. <https://doi.org/10.13700/j.bh.1001-5965.2022.0602>.

- [17] ZHOU X, WANG D Q, & KRÄHENBÜHL P. Objects as points[J]. arXiv preprint arXiv: 1904.07850, 2019.
- [18] 贾晓芬, 于业齐, 郭永存, 等. 航拍绝缘子自爆缺陷的轻量化检测方法[J]. 高电压技术, 2023, 49(1): 294-300.
- JIA Xiaofen, YU Yeqi, GUO Yongcun, et al. Lightweight detection method of self-explosion defect of aerial photo insulator[J]. High

Voltage Engineering, 2023, 49(1): 294-300.

- [19] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.
- [20] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint arXiv: 1704.04861, 2017.
- [21] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[C]// 4th International Conference on Learning Representations. San Juan, Puerto Rico: ICLR, 2015.



王道累

1981—, 男, 博士, 教授, 硕导
主要从事绝缘子检测、输变电设备故障检测、深度学习、CAD/CAM 方面的研究工作
E-mail: alfredwdl@shiep.edu.cn

WANG Daolei
Ph.D., Professor



赵文彬

1976—, 男, 博士, 高工, 硕导
主要从事设备故障诊断、高电压及其绝缘、液体与气体放电等方面的研究工作
E-mail: Zhaowenbin@shiep.edu.cn

ZHAO Wenbin
Ph.D.
Senior engineer



张世恒

1997—, 男, 硕士生
研究方向为机器视觉、设备故障识别
E-mail: 1050724355@qq.com

ZHANG Shiheng



朱 瑞(通信作者)

1981—, 女, 博士, 教授, 硕导
主要从事绝缘子检测、输变电设备故障检测、深度学习方面的研究工作
E-mail: zhuruish@163.com

ZHU Rui
Ph.D., Professor
Corresponding author



袁斌霞

1986—, 女, 博士, 副教授, 硕导
主要研究方向为能源材料制备、力学性能研究、热障涂层等方面
E-mail: yuanbinxia100@163.com

YUAN Binxia
Ph.D.
Associate professor

收稿日期 2022-09-15 修回日期 2023-03-06 编辑 曾文君